基于数据对齐方法的错误相关脑电识别

孙劲松[1], 何峰[1], 王 昊[1], 孟佳圆[1], 许敏鹏[1]

（1. 天津大学医学工程与转换医学研究院 天津 300072）

摘 要：缺乏训练本导致的脑电识别正确率不足是阻碍错误相关电位（ErrP）脑机接口实用化的重要难题。为提升有限训练样本条件下的ErrP识别效果,本研究提出一种基于数据对齐策略的迁移判别子空间分析（TDSA）算法。该算法提取源受试者与目标受试者脑电样本中体现类间差异信息的共有判别子空间,通过子空间中的时域对齐策略,成功强化了受试者之间的共有特征。研究使用2个公开数据集,对比6种不同数据对齐迁移学习策略。结果表明,小样本条件下TDSA算法在数据集1中的平衡正确率相较次优的基于欧式对齐方法提高6.07%,相较不使用迁移学习方法提高7.88%。TDSA算法仅需60～100个目标受试者数据样本训练,即可接近传统分类策略使用210～350个样本进行训练的分类水平,为实现ErrP数据对齐提供了新思路。

关键词：迁移学习；数据对齐；脑机接口；错误相关电位；脑电图

中图分类号:TH79 **文献标识码**：A **国家标准学科分类代码**： 510.40

Data Alignment Approach for Error-related EEG Recognition

Sun Jinsong[1], He Feng[1], Wang Hao[1], Meng Jiayuan[1], Xu Minpeng[1]

（1.Academy of Medical Engineering and Translational Medicine, Tianjin University, Tianjin 300072, China)

Abstract: The limited training samples pose a significant obstacle to the practical application of brain-computer interface based on error-related potentials (ErrPs), affecting their recognition accuracy. To enhance ErrP recognition under such constraints, we propose a transfer discriminant subspace analysis (TDSA) algorithm that leverages a data alignment strategy. This algorithm extracts a shared discriminant subspace from electroencephalogram samples of both source and target subjects, capturing inter-class differences. By applying temporal alignment within this subspace, it effectively reinforces common features across subjects. We evaluate six different data alignment transfer learning strategies using two publicly available datasets. The results demonstrate that the TDSA algorithm achieves a 6.07% improvement in balanced accuracy for dataset 1 compared to the suboptimal Euclidean alignment method and a 7.88% improvement over non-transfer learning methods. Remarkably, with only 60~100 target subject data samples for training, the TDSA algorithm approaches the classification performance of traditional strategies that require 210~350 samples. This provides a new perspective for facilitating the data alignment of ErrPs.

Keywords: **transfer learning; data alignment; brain-computer interfaces; error-related potentials; electroencephalogram**

0 引 言

脑机接口（brain-computer interface, BCI）是一种不依赖外周神经系统和肌肉，直接建立大脑与外部设备之间连接的通信系统[1]。当人意识到错误事件发生时，其大脑会产生名为错误相关电位（error-related potentials，ErrPs）的特征信号。近年来，基于ErrP的BCI（ErrP based BCI，ErrP-BCI）被引入强化学习。研究[2-4]使用受试者观察到人工智能体做出错误行为时产生的ErrP信号设计强化学习的反馈，以实现智能体与人类价值和期望对齐；该策略使机器人的行为随时间逐渐贴合人类意图，在导航等场景中显著减小了用户的任务负荷。同类型技术有望引入人类反馈强化学习，以自然、高效的方式获取反馈标签，解决数据标注成本高等问题。

然而，准确解码ErrP十分困难。受容积传导效应及各种生理伪影和噪声的影响，ErrP的空间分辨率和信噪比极低[5]。ErrP-BCI为提高解码效果，需要大量样本校准分类算法，但采集ErrP样本低效而耗时。以上难题极大程度上限制了ErrP-BCI系统的实用化。

迁移学习可将以往任务中学到的知识和经验用于当前任务[6]。基于数据对齐的迁移学习方法属于特征变换迁移，这类方法通过子空间变换或流形空间变换，减小已有源域受试者与未知目标域受试者之间的数据分布差异，降低现有分类任务收集训练数据的工作量[7]

收稿日期：2020-01-20 Received Date: 2020-01-20（此处具体到日，为投稿日期）
* 基金项目：国家自然科学基金（XXXXXX）项目资助（所有资助必须提供项目编号）

。

由于脑电图（electroencephalogram，EEG）数据信噪比低的特性，传统联合分布自适应[8]、迁移成分分析[9]等方法直接用于EEG数据效果有限。2018年，Rodrigues等人[10]提出黎曼对齐（Riemannian alignment，RA），该方法以对称正定矩阵（symmetric positive definite，SPD）流形上的黎曼距离为度量，以数据的黎曼中心为基准对齐受试者数据。由于黎曼几何框架具有同余不变性、仿射不变性等优良特质，RA算法在运动想象（motor imagery，MI）数据迁移任务中表现出色。2019年，Rodrigues等人[11]进一步提出黎曼普氏分析（Riemannian Procrustes analysis，RPA）算法，该算法将正交强迫一致问题分析框架引入黎曼流形，通过中心化、拉伸、旋转三种变换实现数据对齐。由于考虑了数据条件分布的差异，RPA算法是目前MI数据对齐效果最佳的算法之一。以上两种算法均可用于事件相关电位（event-related potentials，ERPs）数据迁移。近年来，何赫等人[12]提出欧式对齐（Euclidean alignment，EA）算法，该算法在欧式空间中将不同受试者的样本协方差矩阵对齐到单位阵，以实现数据边缘分布对齐。EA在多个ERP与MI数据集中表现优异，相较RA方法，EA算法计算时间更低且可用于无监督ERP数据迁移任务。

ErrP作为一种ERP数据，其类别间时域波形差异是分类的主要依据。然而现有EEG数据对齐算法均未针对其时域特征锁时锁相特点设计，故难以实现ErrP数据的充分迁移。为此，本文提出一种迁移判别成分分析（transfer discriminative subspace analysis，TDSA）算法，该算法计算受试者之间的共有判别成分，创新性地提出一种共有判别成分对齐策略，达成了提升现有ErrP迁移学习效果的目的。

1　基于数据对齐的迁移学习方法

本节介绍空间滤波、TDSA算法及BCI应用中其他基于数据对齐方法的迁移学习策略。

1.1　空间滤波

ErrP-BCI中，正确事件诱发受试者的靶试次响应，错误事件诱发非靶试次响应。设$\boldsymbol{Q}_{i,j} \in R^{N_c \times N_s}$表示受试者隶属类别$i$的第$j$试次EEG响应，其中$i$={0,...,$C$}，$j$∈[1,$N_i$]，$n_s$∈[1,$N_s$]，$n_c$∈[1,$N_c$]，分别表示类别标签、试次序号、数据采样点数目和EEG通道数目。本文中类别标签取i={0,1}，分别对应非靶试次与靶试次，记类别总数T=2。空间滤波则定义为通过空间滤波器$\boldsymbol{W} \in R^{N_c \times k}$将EEG观测值恢复为EEG源的过程[13]：

$$\boldsymbol{s}_i = \boldsymbol{W}^T \boldsymbol{Q}_{i,j} \tag{1}$$

特别指出，此处ERP信号源是数学意义上的子空间，并非表示真实ERP信息源。

1.2　迁移判别子空间分析

1.2.1　问题描述

设$\boldsymbol{Q}_{i,j}$、$\boldsymbol{Q}_j^*$与$\boldsymbol{Q}_{i,j}^n$分别表示已知标签的目标受试者EEG样本、标签未知的目标受试者EEG样本和第n名源受试者的EEG样本。第n名源受试者的样本构成源域数据$\boldsymbol{S}^n$，如式（2）所示：

$$\boldsymbol{S}^n = \{\boldsymbol{Q}_{i,j}^n, i \in \{0,1\}, j \in [1, N_i^n]\} \tag{2}$$

N_i^n为第n名源受试者类别i的样本数量。目标受试者已知标签的样本记为$\boldsymbol{T}_l$，标签未知的样本记为$\boldsymbol{T}_u$，如式（3）与式（4）所示：

$$\boldsymbol{T}_l = \{\boldsymbol{Q}_{i,j}, i \in \{0,1\}, j \in [1, N_i]\} \tag{3}$$

$$\boldsymbol{T}_u = \{\boldsymbol{Q}_j^*, j \in [1, N_{ul}]\} \tag{4}$$

其中N_{ul}为标签未知的样本数量。我们的目标是训练一个分类器，该分类器利用来自$\boldsymbol{S}^n$和$\boldsymbol{T}_l$的可用信息，对来自$\boldsymbol{T}_u$的数据样本具有良好的分类性能。

1.2.2　协方差矩阵对齐

现共有K名源受试者，假设数据均已经过中心化处理。首先，算法分别计算目标受试者和第n名源受试者单试次协方差矩阵的算术平均值$\boldsymbol{R}$与$\boldsymbol{R}^n$：

$$\boldsymbol{R} = \frac{1}{N} \sum_{i,j} \boldsymbol{Q}_{i,j} \boldsymbol{Q}_{i,j}^T \tag{5}$$

$$\boldsymbol{R}^n = \frac{1}{N^n} \sum_{i,j} \boldsymbol{Q}_{i,j}^n \boldsymbol{Q}_{i,j}^{n\,T} \tag{6}$$

其中，N与N_n分别表示目标受试者和第n名源受试者的样本总数。对目标受试者样本和第n名源受试者样本做如下变换：

$$\boldsymbol{X}_{i,j} = \boldsymbol{R}^{-1/2} \boldsymbol{Q}_{i,j} \tag{7}$$

$$\boldsymbol{X}_{i,j}^n = \boldsymbol{R}^{n\,-1/2} \boldsymbol{Q}_{i,j}^n \tag{8}$$

经上述变换，目标受试者的协方差矩阵均值和源受试者的协方差矩阵均值均统一为单位阵$\boldsymbol{I}$。该对齐方法由何赫等人[12]提出。

1.2.3　共有判别子空间求解

迁移判别子空间算法拟求解一个子空间，得到表示目标受试者和源受试者各类别数据之间公共差异信息的共有判别成分。设$\boldsymbol{M}_i$与$\boldsymbol{M}_i^n$分别表示目标受试者和第n名源受试者第i类EEG数据的算术平均值，$\boldsymbol{M}$与$\boldsymbol{M}^n$分别表示目标受试者和第n名源受试者总共T

类均值的算术平均值。我们拟寻找一个空间滤波器 $W_n \in R^{k \times N_C}$，同时最大化源受试者 n 和目标受试者样本的类间距离和类内距离之比，最优化问题如下：

$$\arg\max_{W_t} \frac{tr(W_t^T(S_b + S_b^t)W_t)}{tr(W_t^T(S_w + S_w^t)W_t)} \tag{9}$$

其中：

$$S_b = \frac{1}{T}\sum_i (M_i - M)(M_i - M)^T \tag{10}$$

$$S_b^n = \frac{1}{T}\sum_i (M_i^n - M^n)(M_i^n - M^t)^T \tag{11}$$

$$S_w = \sum_{i,j} \frac{1}{TN_i}(X_{i,j} - M_i)(X_{i,j} - M_i)^T \tag{12}$$

$$S_w^n = \sum_{i,j} \frac{1}{TN_i^n}(X_{i,j}^n - M_i^n)(X_{i,j}^n - M_i^n)^T \tag{13}$$

该最优化问题的解可由广义特征值分解求得：

$$(S_b + S_b^n)W_n = (S_w + S_w^n)W_n\Lambda \tag{14}$$

特征值矩阵 Λ 中前 k 个最大特征值对应的特征向量组成我们需要的受试者共有判别子空间 W_n，根据经验，本文实验中取 $k = 10$。

1.2.4 共有判别子成分对齐

使用 W_n 对源受试者的EEG数据进行空间滤波得到共有判别成分 $s_{i,j}^n$：

$$s_{i,j}^n = W_n^T X_{i,j}^n \tag{15}$$

使用 W_n 对目标受试者的EEG数据进行空间滤波得到共有判别成分 $\hat{s}_{i,j}^n$：

$$\hat{s}_{i,j}^n = W_n^T X_{i,j} \tag{16}$$

目标受试者第 i 类共有判别成分的模板 $\hat{m}_i$ 为：

$$\hat{m}_i^n = \frac{1}{N_i^n}\sum_j \hat{s}_{i,j}^n \tag{17}$$

我们拟寻找一个时域投影矩阵 $P_i^n \in R^{N_S \times N_S}$ 使得第 n 名源受试者的第 i 类共有判别成分 $s_{i,j}^n$ 与目标受试者第 i 类判别成分的模板 $\hat{m}_i$ 对齐，最优化问题如下：：

$$\arg\min_{P_i} \frac{(1-\theta)}{N_i^n}\sum_j \left\|s_{i,j}^n P_i^n - \hat{m}_i^n\right\|_F^2 + \theta\left\|P_i^n\right\|_F^2, i = 1,\cdots C \tag{18}$$

由于ERP数据的采样点数 N_s 通常较多，导致投影矩阵 P_i^n 的待估计参数量大，考虑结构风险最小化，此处为算法添加正则化项 $\|P_i^n\|_F^2$ 以缓解过拟合，其中 θ 为正则化系数；根据经验，本文实验中取 $\theta = 0.1$。该问题属于典型凸优化问题，其最优解可由拉格朗日乘子法求得：

$$P_i^n = \frac{(1-\theta)}{N_i^n}\left[\Sigma_i^n + \theta I\right]^{-1} m_i^{n\,T}\hat{m}_i^n \tag{19}$$

其中，

$$\Sigma_i^n = \frac{(1-\theta)}{N_i^n}\sum_j s_{i,j}^n s_{i,j}^{n\,T} \tag{20}$$

$$m_i^n = \frac{1}{N_i^n}\sum_j s_{i,j}^n \tag{21}$$

经矩阵 P_i^n 投影，可将第 n 名源受试者的判别子成分对齐到目标受试者的共有判别子成分：

$$\tilde{s}_{i,j}^n = s_{i,j}^n P_i^n \tag{22}$$

1.2.5 建立分类模型

计算第 n 名源源受试者共有判别成分 $s_{i,j}^n$ 和对齐后的共有判别成分 $\tilde{s}_{i,j}^n$，计算目标受试者的共有判别成分 $\hat{s}_{i,j}^n$，三者一同构成对应源受试者 n 的训练集 T^n；然后沿子空间与时间维度向量化 T^n 得到最终用于训练分类模型的训练集 T_{train}^n：

$$T^n = \left\{\{s_{i,j}^n\}_{i,j}, \{\tilde{s}_{i,j}^n\}_{i,j}, \{\hat{s}_{i,j}^n\}_{i,j}\right\} \in R^{(2N_n+N)\times k\times N_s} \tag{23}$$

$$T_{train}^n = vect(T_{train}^n) \in R^{(2N_n+N)\times(k\times N_s)} \tag{24}$$

最终可得共计 K 个不同的训练集， 其中$vect(*)$为向量化函数。我们为每个训练集 T_{train}^n 训练一个对应的收缩线性判别分析（shrinkage linear discriminant analysis，SKLDA）[5]分类器 f_n，得到 K 个SKLDA分类器。

目标受试者标签未知的第 j 个试待测EEG样本 Q_j^* 依次经协方差矩阵对齐、共有判别成分提取、向量化操作后成为最终测试样本 t_j^n：

$$t_j^n = vect\left(W_n^T R^{-1/2} Q_i^*\right) \in R^{1\times(k\times N_s)} \tag{25}$$

第 n 个分类器对样本 t_j^n 的决策值为 $f_n(t_j^n)$，最终目标被第 j 个试待测EEG样本的预测标签为：

$$\frac{1}{2}(1 - sign(\frac{1}{K}\sum_n f_n(t_j^n))) \tag{26}$$

其中，$sign(*)$ 为符号函数，大于零的值取1，小于0的值取-1。TDSA算法的整体架构如图1所示。

收稿日期：2020-01-20　Received　Date: 2020-01-20（此处具体到日，为投稿日期）
* 基金项目：国家自然科学基金（XXXXXX）项目资助（所有资助必须提供项目编号）

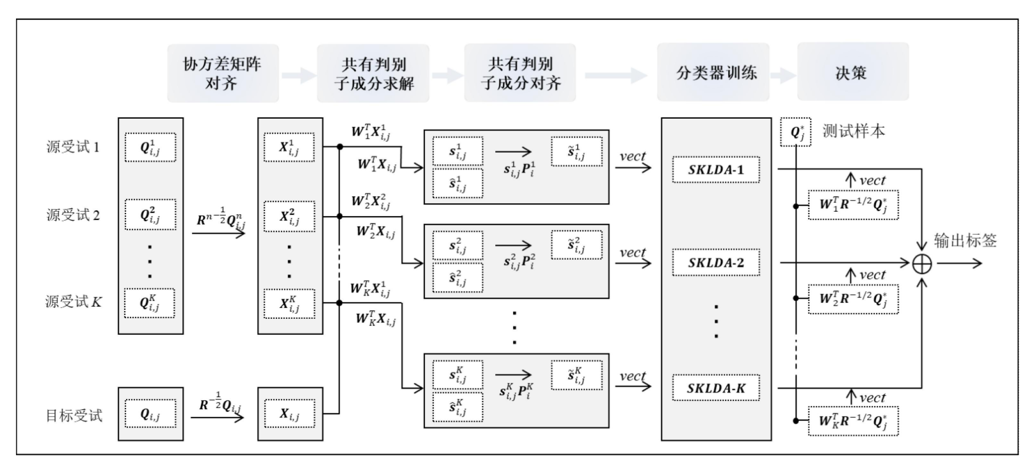


图1 迁移判别子空间分析算法框架

Fig.1 The framework of TDSA

1.3 基于数据对齐的其他迁移学习方法

（1）基于黎曼对齐的迁移学习方法

RA算法对齐的是单试次EEG协方差矩阵 $\{\boldsymbol{\Sigma}_j\}_{j=1}^{N}$ ，该算法旨在求取一个转换矩阵 $\overline{\boldsymbol{R}}$ 使得EEG协方差矩阵 $\boldsymbol{\Sigma}_j$ 的均值对齐到单位阵。 $\overline{\boldsymbol{R}}$ 定义为EEG协方差矩阵的黎曼均值，是以下最优化问题的最优解：

$$\arg\min_{\overline{\boldsymbol{R}}} \sum_j \delta^2\left(\overline{\boldsymbol{R}}, \boldsymbol{\Sigma}_j\right) \tag{27}$$

其中， $\delta(*)$ 为黎曼距离度量。RA对单试次协方差矩阵样本做如下运算：

$$\widetilde{\boldsymbol{\Sigma}}_j = \overline{\boldsymbol{R}}^{-1/2} \boldsymbol{\Sigma}_j \overline{\boldsymbol{R}}^{-1/2} \tag{28}$$

$\widetilde{\boldsymbol{\Sigma}}_j$ 为对齐后的单试次协方差矩阵。因RA算法基于黎曼几何框架构建，对齐后数据的特征识别也需使用基于黎曼流形作为距离度量的分类方法，本文使用相关研究中常用的到黎曼均值最小距离（minimum distance to riemannian mean, MDRM）[14]算法进行模式识别。

（2）基于欧氏对齐的迁移学习方法

EA 算法细节已在 1.2.1 节中介绍，此处不再赘述。本研究受试者数据经 EA 对齐后，使用判别空间模式（discriminative spatial pattern, DSP）[15]算法进行特征提取，使用 SKLDA 进行分类。Yasemin 等人[16]在多个 ErrP 数据集上对 ErrP 常用分类流程做出系统测试，DSP 与 SKLDA 组合的分类流程表现优异。

（3） 基于协方差矩阵质心对齐的迁移学习方法

协方差矩阵质心对齐（covariance matrix centroid alignment，CA）作为流形嵌入知识迁移算法的一部分由伍冬睿等人[17]于2020年提出。该算法旨在寻找一个转换矩阵 $\overline{\boldsymbol{R}}$ 使得各受试者数据的边缘分布接近。此处， $\overline{\boldsymbol{R}}$ 定义为各协方差矩阵的对数－欧式均值：

$$\overline{\boldsymbol{R}} = \exp\left(\frac{1}{N}\sum_j \log(\boldsymbol{\Sigma}_j)\right) \tag{29}$$

CA对齐的形式如式（28）所示。单试次EEG协方差矩阵样本经CA对齐后，使用切空间分类器（tangent space classifier，TSclassifier）[14]进行后续模式识别。

（4）基于黎曼普氏分析的迁移学习方法

RPA算法是一种半监督数据对齐方法，该算法在多个MI数据集中较常用算法表现出显著性能优势。因算法流程较为复杂，文章篇幅有限，此处不做详细介绍。本文实验使用原文作者所提供的算法（https://github.com/plcrodrigues/RPA）。

ERP信号信噪比极低，单试次ERP中噪声能量占据主要地位，因此单试次协方差矩阵 $\boldsymbol{\Sigma}_j$ 难以捕获ERP特有的锁时锁相特征。在实践中，研究者使用RA、CA、RPA算法执行迁移学习任务时，通常构建扩增试次数据 $\boldsymbol{Q}_{i,j}^{\arg}$ 以计算样本协方差矩阵[18]：

$$\boldsymbol{Q}_{i,j}^{\arg} = \left[\boldsymbol{Q}_{i,j}{}^{T}, \overline{\boldsymbol{M}}_1{}^{T}\right]^{T} \in R^{2N_C \times N_S} \tag{30}$$

其中， $\overline{\boldsymbol{M}}_1$ 为已知标签目标域数据中靶试次的算术平均值。

2 实验验证

本节介绍算法验证所使用的数据集、预处理方法、测试流程、实验设置和结果。

2.1 实验数据集与预处理方法

（1）数据集1

数据集1为人-机器人交互光标（Human–robot interaction cursor，HRIcursor）公开数据集，共包含11名受试者数据。试验要求受试者观察机器人的动作、屏幕上的光标运动及运动结束后屏幕中给出的反馈；当机器人所示意的光标运动方向和实际的光标运动方向不一致时，屏幕给出的反馈会诱发受试者产生ErrP响应。试验具体细节详见Ehrlich等人[19]的研究。试验过程中受试者佩戴32导联EEG帽采集大脑活动数据，其中包括3个眼电（electrooculogram，EOG）电极，电极位置符合国际10-20电极排布系统要求，参考电极为左右乳突电极的平均值。每名受试者有500试次EEG样本，含有ErrP信号的靶试次占比为31～42%。

（2）数据集2

数据集2为人-机器人机交互互适应（Human–robot interaction co-adaptation，HRIcoadapt）公开数据集，共包含16名受试者数据。试验要求受试者观察机器人和屏幕呈现的反馈。试验中机器人将给出暗示，然后注视前方位于三个不同位置的物品，受试者需要根据机器人的暗示猜测其将要注视的物品；当机器人实际注视的物品与受试者的猜测不一致时，屏幕呈现的反馈将诱发受试者产生ErrP响应。试验具体细节详见Ehrlich等人[20]的研究。数据采集方法与数据集1一致。每名受试者约有300试次EEG样本，其中含有ErrP信号的靶试次占比为29～60%。特别指出，只有受试者内部ErrP分类平衡正确率高于随机水平的受试者才有充足的可供迁移的有用信息。故数据集2中仅10名受试者数据用于后续试验分析，该做法常见于相关研究[11]。

（3）预处理方法

数据预处理时，首先丢弃3个EOG电极，数据经1-10 Hz带通滤波后降采样至128 Hz，数据由左右乳突平均参考转为共平均参考。数据集2中数据以电脑反馈出现的时刻为0时刻，截取前0.2 s后0.5 s的数据，前0.2 s的数据用于去基线，后0.6 s数据用于分类任务。考虑数据集1实验范式设计差异，数据分段步骤截取电脑反馈后0.6 s的数据用于分类，不执行去基线操作。

2.2 算法测试流程与实验设置

（1）对比算法

实验测试的分类流程共7种，TDSA分类过程已详细介绍，其余6种总结如下：

1）受试者内分类（calibration， cali）：将目标受试者数据划分为已知标签的目标域数据 $\boldsymbol{T}_l$ 和标签未知的目标域数据 $\boldsymbol{T}_u$，使用 $\boldsymbol{T}_l$ 训练算法，使用 $\boldsymbol{T}_u$ 测试算法性能，流程与常规EEG分类一致。该分类流程使用DSP算法提取特征，然后使用SKLDA执行模式识别。

2）直接分类（direct，DCT）：将目标受试者数据划分为 $\boldsymbol{T}_l$ 和 $\boldsymbol{T}_u$，源受试者数据不做任何处理与目标受试者训练集数据组合成一个更大的训练集 $\{\boldsymbol{T}_l,\boldsymbol{S}^1,\cdots,\boldsymbol{S}^K\}$，在该训练集上训练算法，在 $\boldsymbol{T}_u$ 测试算法性能。使用DSP算法提取特征，然后使用SKLDA执行模式识别。

3）基于数据对齐的迁移学习方法：主要为1.3节介绍的4种分类流程：EA+DSP+SKLDA、RA+MDRM、CA+TSclassifier、RPA+MDRM。算法测试时，将目标受试者数据划分为 $\boldsymbol{T}_l$ 和 $\boldsymbol{T}_u$，逐一将源受试者数据 $\boldsymbol{S}^n$ 与已知标签的目标域数据 $\boldsymbol{T}_l$ 对齐并组成训练集 $\boldsymbol{T}_{train}^n=\{\boldsymbol{T}_l,\boldsymbol{S}^n\}$，为每个训练集训练对应的分类器，共得到 K 个分类器，最终决策方式与1.2.5节所述方式相同。具体分类流程如图2所示。

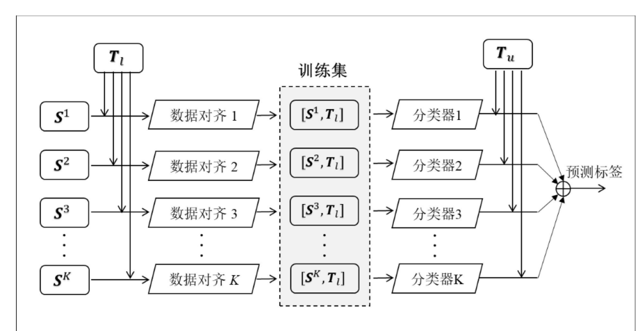


图2 基于数据对齐的迁移学习方法分类流程图

Fig.2 The classification framework of data alignment based transfer learning

（2）实验设置

为测试算法性能随 $\boldsymbol{T}_l$ 中样本数量的变化情况，实验选择一名受试者为目标受试者，其余受试者为源受试者，并随机抽取占目标受试者样本总数不同比例（10%，20%，30%，40%，50%，60%，70%）的数据构成 $\boldsymbol{T}_l$，在剩余数据中随机抽取30%目标受试者样本总数的数据构成 $\boldsymbol{T}_u$，算法依次在不同大小的 $\boldsymbol{T}_l$ 上进行迁移学习与训练，在 $\boldsymbol{T}_u$ 上进行性能评估；实验依次选择每名受试者作为目标受试者，直到数据集中所有受试者均当选过目标受试者后结束。以上过程重

收稿日期：2020-01-20　　Received　Date: 2020-01-20（此处具体到日，为投稿日期）
* 基金项目：国家自然科学基金（XXXXXX）项目资助（所有资助必须提供项目编号）

复20轮，取20轮评估结果的平均值作为最终结果。

（3）算法性能指标

ErrP识别属于非平衡样本的分类问题，考虑样本不平衡因素的影响，研究者通常选择平衡正确率（balanced accuracy，bAcc）作为评价算法性能的指标。bAcc为真阳率与真阴率的平均值，真阳率为测试集中被正确识别为靶的样本数目占靶样本总数的比例，真阴率为测试集中被正确识别为非靶的样本总数占非靶样本总数的比例。

2.3 算法分类性能随T_l样本数目的变化情况

本文提出TDSA算法在两个数据集中相较其他基于数据迁移的分类策略均表现出显著性能优势。表1、表2为两数据集中T_l样本数目占比10%（50个样本）条件下不同迁移学习方法对受试者的分类性能。实验使用单尾配对样本t检验分析了每种分类策略与TDSA算法之间bAcc均值的差异，p值经FDR方法校正。数据集1中，TDSA算法在所有受试者中均取得最佳分类性能，平均bAcc相较次优的EA+DSP+SKLDA策略高出6.07%（$p<0.01$），相较不使用数据迁移的cali策略高出7.88%（$p<0.01$）。数据集2种，TDSA算法分类表现弱于数据集1，但分类水平仍高于其他策略，且差异具有统计学意义。

表1 数据集1中T_l数据占比10%条件下不同迁移学习方法对11名受试者的ErrP分类性能对比

Table 1 Comparison ErrP classification performance of transfer learning methods among 11 subjects under the condition of T_l data accounting for 10% in dataset-1

受试者	平衡正确率（%）						
	cali	DCT	EA	RA	CA	RPA	TDSA
1	72.66	77.84	72.08	69.86	68.91	72.58	**81.26**
2	70.87	69.62	75.87	79.58	75.12	67.88	**80.55**
3	86.92	81.66	88.65	89.46	87.48	89.25	**91.53**
4	75.45	71.22	77.13	73.24	71.69	70.58	**82.88**
5	69.01	71.88	79.61	77.44	72.54	61.20	**84.87**
6	86.50	76.03	89.55	83.50	83.65	84.60	**93.15**
7	76.63	66.22	75.36	71.75	74.41	77.66	**80.75**
8	83.13	79.47	86.63	85.69	82.88	82.32	**89.86**
9	78.80	47.67	72.22	76.16	75.47	67.06	**82.68**
10	77.38	71.85	77.77	72.79	72.15	63.64	**84.95**
11	75.92	70.50	78.35	73.19	77.14	64.84	**87.49**
均值	77.57	71.27	79.38	77.51	76.49	72.87	**85.45**
标准差	5.64	8.67	5.91	6.05	5.52	8.88	4.25
p	<0.01	<0.01	<0.01	<0.01	<0.01	<0.01	-

表2 数据集2中T_l数据占比10%条件下不同迁移学习方法对10名受试者的ErrP分类性能对比

Table 2 Comparison ErrP classification performance of transfer learning methods among 10 subjects under the condition of T_l data accounting for 10% in dataset-2

受试者	平衡正确率（%）						
	cali	DCT	EA	RA	CA	RPA	TDSA
1	68.94	75.88	77.29	54.48	71.66	59.03	**78.64**
2	62.77	75.38	**78.23**	56.49	59.98	54.23	77.72
3	53.94	55.41	**60.32**	51.17	59.46	59.19	60.12
4	71.95	68.67	**86.43**	67.37	73.02	67.39	86.11
5	72.08	78.49	85.15	53.97	68.77	57.82	**86.81**
6	50.87	53.62	55.87	53.00	55.97	53.31	**58.1**
7	68.66	72.95	73.82	50.71	62.95	67.89	**76.66**
8	66.5	71.54	78.77	71.80	71.88	68.34	**80.18**
9	**62.05**	50.11	56.49	50.92	53.49	49.85	61.20
10	61.01	60.81	**68.58**	66.02	63.44	69.94	68.43
均值	63.88	66.29	72.10	57.59	64.06	60.70	**73.40**
标准差	6.85	9.86	10.7	7.39	6.62	6.84	10.14
p	<0.01	<0.01	0.018	<0.01	<0.01	<0.01	-

图3、图4为迁移算法性能随T_l中样本数量的变化情况，图中误差线为标准差。结果表明，TDSA算法在所有样本数量条件下相较其他算法均表现出最佳性能。TDSA算法通过迁移源域受试者的已知信息，仅需60～100个被标记的目标受试者样本训练算法，即可接近cali策略使用210～350个样本训练算法时的分类水平。这一结果说明，TDSA算法可以充分利用已有受试者数据减少ErrP-BCI系统的校准时间，从而显著提高ErrP-BCI系统的易用性。

此外，基于黎曼几何框架的RA、RPA算法处理ErrP数据迁移问题时表现不佳，该现象与研究[11]中RPA处理P300数据迁移问题时效果表现劣于同类算法的结果类似；该结果表明，现有基于黎曼的迁移学习框架需要做出调整才能适用于ErrP数据迁移。

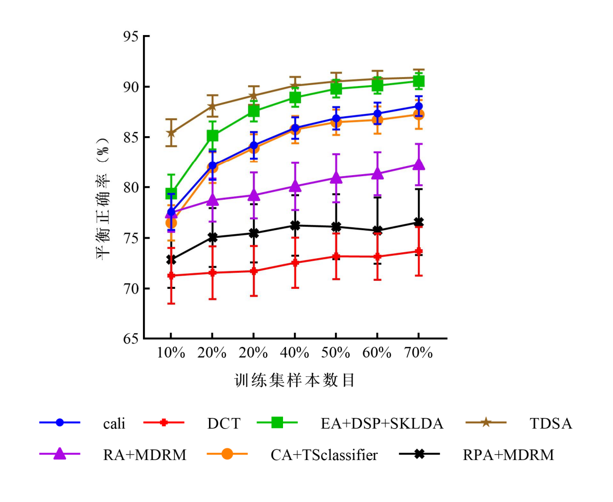


图3 数据集1中算法性能随T_l大小数量的变化

Fig.3 Algorithm performance in dataset-1 with different sizes of T_l

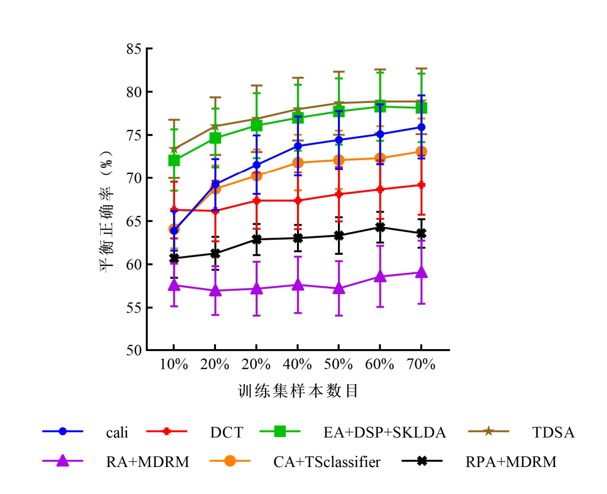


图4　数据集2中算法性能随T_l大小数量的变化

Fig.4 Algorithm performance in dataset-2 with different sizes of T_l

2.4　共有判别子成分对齐效果

为考察共有判别子成分对齐的作用效果，在使用TDSA进行迁移学习的过程中，使用*t*分布随机近邻嵌入（*t*-distributed stochastic neighbor embedding，*t*-SNE）算法对共有判别子成分对齐前数据$\{s_{i,j}^n \mid n\in[1,K], j\in\{0,1\}, i\in[1,N_i]\}$与对齐后数据$\{\tilde{s}_{i,j}^n \mid n\in[1,K], j\in\{0,1\}, i\in[1,N_i]\}$的分布情况进行可视化。实验使用数据集1中9号受试者作为目标受试者，令T_l中样本数目占9号受试者样本总数10%，以其他作为源受试者展开实验，结果如图5所示。可见，共有判别子空间对齐策略可以有效提高靶类别和非靶类别之间的分布差异从而提升ErrP识别效果。

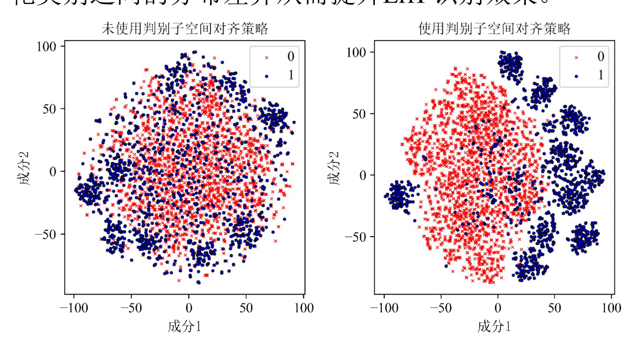


图5　共有判别子成分对齐策略对数据分布的影响

Fig.5 Effect of common discriminant subcomponent alignment strategy on data distribution

2.5　算法计算成本对比

本研究实验的环境为：Intel（R）Core i9-12900K处理器，64G内存，64位Windows 11系统，算法使用Python 3.10实现。各迁移学习策略的计算成本如图6所示，图中结果为T_l中样本数目占目标受试者样本总数10%（50个样本）条件下，所有受试者训练时间的平均值，图中误差线为标准差。可知TSDA算法计算成本与EA+DSP+SKLDA近似，完成迁移学习与分类器构建耗时约为8.38 s，显著低于EA、RA、CA等基于非欧距离度量的迁移学习方法，具有良好的计算经济性。

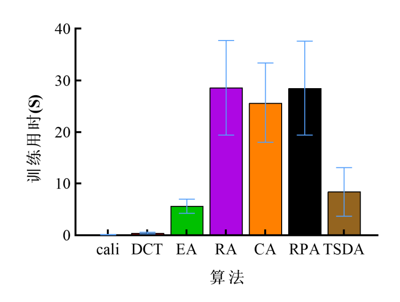


图6　各迁移学习策略计算用时

Fig.6 Computational time of different transfer learning strategies

3　结　论

针对当前ErrP-BCI校准时间长的问题，本文提出一种基于数据对齐策略的TDSA算法。该算法通过共有判别成分空间滤波器提取目标受试者和源受试者所共有的类间差异特征，并进一步在子空间中实现源受试者与目标受试者的时域特征对齐。实验结果表明，TDSA算法利用已有源受试者数据，仅需采集60～100个目标受试者数据作为训练样本，即可接近传统分类策略使用210～350个样本进行训练的分类水平，使得ErrP-BCI校准时间显著降低。研究同时在2个公开数据集上使用交叉验证方法，对比TDSA与其他先进迁执迁移学习策略之间的ErrP分类效果。结果表明，数据集1中仅有50个训练样本的条件下，TDSA相较次优的EA+DSP+SKLDA策略高出6.07%，相较不使用数据迁移的传统策略高出7.88%。因此，本文提出的TDSA算法可有效降低现有ErrP-BCI系统校准所需的EEG样本数目，为解决ERP数据迁移问题提供了新的思路。

参考文献

[1]　WOLPAW J R, BIRBAUMER N, MCFARLAND D J, et al. Brain–computer interfaces for communication and

收稿日期：2020-01-20　　Received　Date: 2020-01-20（此处具体到日，为投稿日期）
* 基金项目：国家自然科学基金（XXXXXX）项目资助（所有资助必须提供项目编号）

control[J/OL]. Clinical Neurophysiology, 2002, 113(6): 767-791.
[2] ZANDER T O, KROL L R, BIRBAUMER N P, et al. Neuroadaptive technology enables implicit cursor control based on medial prefrontal cortex activity[J/OL]. Proceedings of the National Academy of Sciences, 2016, 113(52): 14898-14903.
[3] WANG X, CHEN H T, LIN C T. Error-related potential-based shared autonomy via deep recurrent reinforcement learning[J/OL]. Journal of Neural Engineering, 2022, 19(6): 066023.
[4] PIRES G, CRUZ A, JESUS D, et al. A new error-monitoring brain–computer interface based on reinforcement learning for people with autism spectrum disorders[J/OL]. Journal of Neural Engineering, 2022, 19(6): 066032.
[5] BLANKERTZ B, LEMM S, TREDER M, et al. Single-trial analysis and classification of ERP components — A tutorial[J/OL]. NeuroImage, 2011, 56(2): 814-825.
[6] WAN Z, YANG R, HUANG M, et al. A review on transfer learning in EEG signal analysis[J/OL]. Neurocomputing, 2021, 421: 1-14.
[7] WU D, XU Y, LU B L. Transfer Learning for EEG-Based Brain–Computer Interfaces: A Review of Progress Made Since 2016[J/OL]. IEEE Transactions on Cognitive and Developmental Systems, 2022, 14(1): 4-19.
[8] LONG M, WANG J, DING G, et al. Transfer Feature Learning with Joint Distribution Adaptation[C/OL]//2013 IEEE International Conference on Computer Vision. Sydney, Australia: IEEE, 2013: 2200-2207[2024-04-25]. http://ieeexplore.ieee.org/document/6751384/.
[9] PAN S J, TSANG I W, KWOK J T, et al. Domain Adaptation via Transfer Component Analysis[J/OL]. IEEE Transactions on Neural Networks, 2011, 22(2): 199-210.
[10] ZANINI P, CONGEDO M, JUTTEN C, et al. Transfer Learning: A Riemannian Geometry Framework With Applications to Brain–Computer Interfaces[J/OL]. IEEE Transactions on Biomedical Engineering, 2018, 65(5): 1107-1116.
[11] RODRIGUES P L C, JUTTEN C, CONGEDO M. Riemannian Procrustes Analysis: Transfer Learning for Brain–Computer Interfaces[J/OL]. IEEE Transactions on Biomedical Engineering, 2019, 66(8): 2390-2401.
[12] HE H, WU D. Transfer Learning for Brain–Computer Interfaces: A Euclidean Space Data Alignment Approach[J/OL]. IEEE Transactions on Biomedical Engineering, 2020, 67(2): 399-410.
[13] HAUFE S, MEINECKE F, GÖRGEN K, et al. On the interpretation of weight vectors of linear models in multivariate neuroimaging[J/OL]. NeuroImage, Improving Covariance Matrices Derived from Tiny Training Datasets for the Classification of Event-Related Potentials with Linear Discriminant Analysis, 87: 96-110.
[14] BARACHANT A, BONNET S, CONGEDO M, et al. Multiclass Brain–Computer Interface Classification by Riemannian Geometry[J/OL]. IEEE Transactions on Biomedical Engineering, 2012, 59(4): 920-928.
[15] PIRES G, NUNES U, CASTELO-BRANCO M. Statistical spatial filtering for a P300-based BCI: Tests in able-bodied, and patients with cerebral palsy and amyotrophic lateral sclerosis[J/OL]. Journal of Neuroscience Methods, 2011, 195(2): 270-281.
[16] YASEMIN M, CRUZ A, NUNES U J, et al. Single trial detection of error-related potentials in brain–machine interfaces: a survey and comparison of methods[J/OL]. Journal of Neural Engineering, 2023, 20(1): 016015.
[17] ZHANG W, WU D. Manifold Embedded Knowledge Transfer for Brain-Computer Interfaces[J/OL]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2020, 28(5): 1117-1127.
[18] BARACHANT A, CONGEDO M. A Plug&Play P300 BCI Using Information Geometry[M/OL]. arXiv, 2014[2024-04-01]. http://arxiv.org/abs/1409.0107.
[19] EHRLICH S K, CHENG G. A Feasibility Study for Validating Robot Actions Using EEG-Based Error-Related Potentials[J/OL]. International Journal of Social Robotics, 2019, 11(2): 271-283.
[20] EHRLICH S K, CHENG G. Human-agent co-adaptation using error-related potentials[J/OL]. Journal of Neural Engineering, 2018, 15(6): 066014.